УДК 004.93

А.А. Олейник
Запорожский национальный технический университет, Украина
subbotin@zntu.edu.ua

Мультиагентный метод оптимизации с адаптивными параметрами*

Исследован мультиагентный подход к оптимизации многомерных нелинейных функций. Разработан мультиагентный метод оптимизации с адаптивными параметрами. Проведены эксперименты по поиску глобального оптимума многомерной функции на основе предложенного метода.

Введение

Градиентные методы безусловной оптимизации, традиционно применяемые при синтезе моделей сложных объектов и систем, являются высокоитеративными и накладывают определенные требования (например, унимодальность, непрерывность, монотонность, дифференцированность и т.п.) к виду целевой функции, а также, как правило, являются методами локального поиска.

Поэтому актуальной является задача разработки новых методов оптимизации, не выдвигающих подобные требования к целевым функциям. В связи с этим возникает интерес к методам, основанным на случайном поиске, которые характеризуются большей скоростью работы, а также не накладывают никаких требований на зависимости, которые исследуются. К таким методам относятся мультиагентные методы интеллектуальной оптимизации, которые имеют бионическую природу и основаны на моделировании поведения коллективного интеллекта социальных живых существ (Swarm Intelligence) [1], [2]. К интеллектуальным методам мультиагентной оптимизации, основанным на моделировании общественного интеллекта, относятся: метод муравьиных колоний (Ant Colony Optimization, ACO) [3], [4]; метод пчелиной колонии (Bee Colony Optimization, BCO) [5], [6]; оптимизация с использованием роя частиц (Particle Swarm Optimization, PSO) [7] и другие методы [8]. Данные методы уже эффективно применяются для решения разных задач оптимизации [3-10].

Постановка задачи

Метод оптимизации с использованием роя частиц традиционно используется для решения задачи поиска глобального оптимума многомерной функции, где показал довольно хорошие результаты [11], [12]. Однако PSO-метод характеризуется и недостатками, связанными с возможностью слишком быстрого изменения скорости частиц, что приводит к увеличению времени поиска оптимального решения.

* Работа выполнена в рамках госбюджетной темы «Информационные технологии автоматизации распознавания образов и принятия решений для диагностики в условиях неопределенности на основе гибридных нечетко-логических, нейросетевых и мультиагентных методов вычислительного интеллекта» кафедры «Программных средств» Запорожского национального технического университета (номер государственной регистрации 0109U007673).

Цель данной работы – разработка модификации метода оптимизации с использованием роя частиц путем введения дополнительных процедур с целью исключения его недостатков, связанных с лавиноподобным изменением скорости частиц, что позволит улучшить оптимизационный процесс.

Основными **задачами** работы являются:

– исследование метода оптимизации с использованием роя частиц;

– выявление основных недостатков исследуемого метода;

– создание метода оптимизации на основе моделирования поведения роя частиц, исключающего основные недостатки базового метода;

– разработка программного обеспечения, реализующего предложенный метод, и его тестирование.

Мультиагентный метод оптимизации с использованием роя частиц

В PSO-методе агенты, называемые частицами, перемещаются в многомерном пространстве решений. Изменения координат частиц внутри пространства поиска обусловливаются естественной социально-психологической тенденцией частиц конкурировать между собой. Итак, изменения состояний частицы зависят от опыта и знаний ее соседей. В этом случае слово «знание» является синонимом «информации». Результат такого моделирования заключается в том, что процесс поиска мотивирует частицы недетерминированным образом возвращаться в оптимальные участки пространства решений.

Агенты в рое частиц имеют очень простое поведение: они стремятся превзойти достижение соседних частиц и улучшить собственные. Таким образом, емерджентное свойство данной системы состоит в исследовании оптимальных участков многомерного пространства поиска.

PSO-метод управляет роем частиц и каждая частица представляет собой потенциальное решение. По аналогии с эволюционными стратегиями, рой можно трактовать как популяцию, а частицу как индивида (или хромосому). Таким образом, частица перемещается в многомерном пространстве решений и ее позиция определяется исходя из собственного опыта и опыта своих соседей.

Метод PSO может быть описан в виде последовательности таких этапов:

– инициализация;

– вычисление значений целевой функции;

– обновление скоростей и позиций частиц;

– проверка критериев останова поиска.

Этап 1. *Инициализация*.

На данном этапе создается множество агентов A ($|A| = n_s$), определяющих точки в n_x-мерном пространстве поиска.

Через $x_i(t)$ обозначим позицию частицы i в пространстве поиска в момент времени t (t обозначает дискретные значения времени). Позиция частицы меняется путем добавления скорости $v_i(t)$ к текущей позиции:

$$x_i(t + 1) = x_i(t) + v_i(t + 1).$$

Начальное состояние определяется таким образом: $x_i(0) = U(x_{\min}, x_{\max})$, где $U(a,b)$ является функцией генерации случайных чисел из диапазона $[a, b]$. Данная формула представляет собой вектор скорости и определяет сам оптимизационный процесс, а также отображает использование как полученных знаний частицы, так и обмен информацией с соседними частицами. Собственные знания самой частицы, которые также

называются *когнитивным компонентом* формулы скорости, прямо пропорциональны текущему расстоянию частицы от ее наилучшего положения, которое было найдено с момента начала ее жизненного цикла. А обмен информацией данной особи (агента) с другими агентами является *социальным компонентом* формулы скорости.

Этап 2. *Вычисление значений целевой функции и определение наилучших позиций*. Данный этап может быть выполнен с помощью следующих шагов.

Шаг 1. Установить: $i = 1$, где i – счетчик, определяющий номер текущего агента.

Шаг 2. Определить локально наилучшую позицию y_i. Если выполнено условие $f(x_i) < f(y_i)$, тогда установить: $y_i = x_i$, где x_i – текущая позиция i-й частицы; $f(x_i)$ и $f(y_i)$ – значения целевой функции f в точках x_i и y_i соответственно.

Шаг 3. Определить глобально наилучшую позицию y^*. Установить: $y^* = y_i$.

Шаг 4. Установить: $i = i + 1$.

Шаг 5. Если $i < n_s$, тогда выполнить переход к шагу 1, в противном случае – перейти к выполнению следующего этапа.

Этап 3. *Обновление скоростей и позиций частиц*.

Известны два подхода, которые являются разновидностями базового PSO-метода: *gbest* и *lbest*, которые отличаются степенью связанности частиц в пространстве поиска.

В gbest PSO-методе скорость частицы рассчитывается по формуле:

$$v_{ij}(t+1) = v_{ij}(t) + c_1 r_{1j}(t)[y_{ij}(t) - x_{ij}(t)] + c_2 r_{2j}(t)[y_j^*(t) - x_{ij}(t)],$$

где $v_{ij}(t)$ – скорость частицы i в измерении j ($j = 1, ..., n_x$) в момент времени t; $x_{ij}(t)$ – позиция частицы i в измерении j; $y^*(t)$ – наилучшая достигнутая позиция роя (в пространстве решений); c_1 и c_2 – положительные константы ускорения, которые используются для варьирования весов когнитивной и социальной компонент скорости частицы соответственно; $r_{1j}(t), r_{2j}(t) = U(0,1)$ являются случайными значениями из диапазона [0, 1]. Эти случайные величины вносят стохастический элемент в работу метода.

Величина y_i отображает наилучшую позицию частицы i, которую она посещала, начиная с первой итерации. Следующая оптимальная позиция частицы i в момент времени $t + 1$ рассчитывается по формуле:

$$y_i(t+1) = \begin{cases} y_i(t), & \text{если} \quad f(x_i(t+1)) \geq f(y_i(t)); \\ x_i(t+1), & \text{если} \quad f(x_i(t+1)) < f(y_i(t)), \end{cases}$$

где $f : \Re^{n_x} \rightarrow \Re$ – целевая функция (фитнесс-функция), $\Re^{n_x}$ – множество значений независимых переменных, $\Re$ – множество значений оптимизируемой величины. Так же, как и в эволюционных подходах, фитнесс-функция является мерой близости данного решения к оптимальному, а также определяет производительность или качество частицы.

В lbest PSO-методе скорость рассчитывается по формуле:

$$v_{ij}(t+1) = v_{ij}(t) + c_1 r_{1j}(t)[y_{ij}(t) - x_{ij}(t)] + c_2 r_{2j}(t)[y^*_{ij}(t) - x_{ij}(t)],$$

где $y^*_{ij}(t)$ – наилучшая позиция, найденная соседями i-й частицы в измерении j. Локально наилучшая позиция частицы y^*_i, то есть лучшая позиция, найденная в соседстве N_i, которое определяется как:

$$y^*_i(t+1) \in \{\mathrm{N}_i \mid f(y^*_i(t+1))\} = \min\{f(x)\}, \forall x \in \mathrm{N}_i\},$$

где соседство N_i определяется по формуле:

$$\mathrm{N}_i = \{y_{i-n_{N_i}}(t), y_{i-n_{N_i}+1}(t), ..., y_{i-1}(t), y_i(t), y_{i+1}(t), ..., y_{i+n_{N_i}}(t)\},$$

для соседства размерностью n_{N_i}.

Алгоритм этапа обновления скоростей и позиций частиц PSO-метода может быть представлен в виде следующей последовательности шагов.

Шаг 1. Установить: $i = 1$.

Шаг 2. Обновить скорость частицы, используя формулу gbest PSO или lbest PSO.

Шаг 3. Обновить позицию частицы.

Шаг 4. Установить: $i = i + 1$.

Шаг 5. Если $i < n_s$, тогда выполнить переход к шагу 2, в противоположном случае – перейти к этапу проверки критериев окончания поиска.

Этап 4. *Проверка критериев окончания поиска*.

Окончание выполнения PSO-метода происходит, если выполняется хотя бы один из критериев останова.

Существуют два аспекта, которые должны быть учтены при выборе подобных мер.

1. Условие останова не должно служить причиной преждевременной сходимости PSO-метода. В противоположном случае будут получены субоптимальные решения.

2. При проверке критериев остановки фитнесс-функция должна вызываться минимальное количество раз, поскольку от этого сильно зависит скорость работы PSO-метода.

В качестве критериев останова, как правило, используют:

– достижение максимально допустимого количества итераций;

– нахождение приемлемого решения;

– отсутствие существенного улучшения значения целевой функции на протяжении некоторого количества итераций;

– выход при условии, что первая производная фитнесс-функции в окраине частицы или частиц равняется нулю.

Мультиагентный метод оптимизации с адаптивными параметрами

Эффективный метод оптимизации должен обладать двумя важными свойствами: максимально полно исследовать пространство решений задачи и дать возможность детализации поиска возле потенциальных оптимумов. В PSO-методе это определяется формулой скорости частиц.

В ранних реализациях PSO-метода было выявлено, что скорости могут слишком быстро возрастать, особенно скорости тех частиц, которые находятся далеко от своего собственного оптимума или общего оптимума своих соседей. В результате, такие частицы могут оставлять пространство поиска, что очень отрицательно влияет на работу метода в целом.

Для предотвращения подобных ситуаций в разработанном мультиагентном методе оптимизации с адаптивными параметрами предложено контролировать диапазон изменения скоростей частиц. Если скорость частицы превышает максимально допустимую, то ее следует снизить к допустимому уровню.

Пусть $V_{max,j}$ – максимально допустимая скорость частицы в измерении j. Тогда скорость частицы предлагается менять таким образом:

$$v_{ij}(t+1) = \begin{cases} v_{ij}^{`}(t+1), \text{ если } v_{ij}(t+1) = V_{\max,j}; \\ V_{\max,j}, \text{ если } v_{ij}^{`}(t+1) \geq V_{\max,j}, \end{cases}$$

где значение $v_{ij}^{`}$ рассчитывается в соответствии с gbest PSO или lbest PSO.

Величина $V_{max,j}$ является довольно важной, поскольку она контролирует общие масштабы поиска. Большие значения заставляют мультиагентный метод исследовать пространство задачи более тщательно. Если значение $V_{max,j}$ является небольшим, то возможны ситуации зацикливания в локальных участках поиска, кроме того, при небольших значениях $V_{max,j}$ увеличивается количество итераций, необходимых для достижения оптимума.

Исходя из вышесказанного очевидно, что в разработанном методе величину $V_{max,j}$ предлагается подбирать таким образом, чтобы балансировать между быстрым и медленным передвижениями частиц и между фиксацией поиска и общим исследованием пространства. Предлагается рассчитывать $V_{max,j}$ таким образом:

$$V_{\max,j} = \delta(x_{\max,j} - x_{\min,j}),$$

где $x_{max,j}$ и $x_{min,j}$ – величины, которые, соответственно, снизу и сверху ограничивают диапазон значений измерения j, а $\delta \in (0,1]$. Очевидно, что величина δ является проблемно-зависимой.

Отметим два важных свойства мультиагентного метода оптимизации с адаптивными параметрами:

1) величина $V_{max,j}$ ограничивает не пространство поиска, внутри которого передвигаются частицы, а только скорости частиц (точнее, диапазон их изменения за одну итерацию);

2) максимальная скорость частиц определяется для каждого измерения отдельно и обусловливается только его физической природой.

Исходя из предложенного подхода можно отметить, что ограничение скорости частицы может вызвать изменение направления ее передвижения, что может как позитивно, так и негативно отражаться на поиске оптимума. Этот эффект изображен на рис. 1, где $x_i(t + 1)$ – это позиция i-й частицы без ограничений на скорость. А величина $x'_i(t+1)$ уже отображает позицию частицы после того, как скорость стала равной $V_{max,j}$.

Нежелательный эффект может возникнуть в случае, если скорости всех частиц станут равными $V_{max,j}$. Для его предотвращения можно предложить с количеством итераций уменьшать значение $V_{max,j}$. Тогда предложенный мультиагентный метод будет последовательно сужать масштабы исследования пространства поиска, что делает оптимизационный процесс более эффективным.

Тогда мультиагентный метод оптимизации с адаптивными параметрами может быть описан в виде последовательности следующих этапов.



Рисунок 1 – Эффект использования ограничения скорости частицы

Этап 1. *Инициализация*. На этапе инициализации создается множество агентов A ($|A| = n_s$), определяющих точки в n_x -мерном пространстве поиска.

Также на этапе инициализации в соответствии с предложенным подходом необходимо рассчитать максимально допустимые скорости частиц:

$$V_{\max,j} = \delta(x_{\max,j} - x_{\min,j}).$$

Этап 2. *Вычисление значений целевой функции и определение наилучших позиций*. Данный этап может быть выполнен в последовательности, приведенной выше.

Этап 3. *Обновление скоростей и позиций частиц*. Для обновления скорости частицы предлагается использовать формулу:

$$v_{ij}(t+1) = \begin{cases} v'_{ij}(t+1), \text{ если } v_{ij}(t+1) = V_{\max,j}; \\ V_{\max,j}, \text{ если } v'_{ij}(t+1) \geq V_{\max,j}. \end{cases}$$

Для выполнения этапа обновления скоростей и позиций частиц в предложенном мультиагентном методе предлагается использовать приведенный выше алгоритм выполнения аналогичного этапа в PSO-методе.

Кроме того на данном этапе необходимо уменьшить величину δ: $\delta = \delta^{\alpha}$, где $\alpha \in (0; 1)$. Уменьшение величины δ приводит к тому, что на следующей итерации будет уменьшена и величина $V_{max,j}$.

Этап 4. *Проверка критериев окончания поиска*. В случае, если критерии окончания поиска удовлетворены, выполняется останов работы метода, в противном случае – переход к этапу вычисления значений целевой функции.

Разработанный мультиагентный метод оптимизации с адаптивными параметрами путем управления изменением скорости частиц исключает нежелательный эффект слишком быстрого возрастания скоростей частиц, что позволяет улучшить оптимизационный процесс за счет уменьшения времени поиска оптимального решения.

Эксперименты и результаты

Предложенный мультиагентный метод оптимизации с адаптивными параметрами был программно реализован в среде пакета Matlab 7.0.

Используя созданное программное обеспечение, проводились эксперименты по поиску оптимального значения функций с целью исследования эффективности предложенного метода по сравнению с известным PSO-методом. Результаты экспериментов с использованием тестовых функций приведены в табл. 1.

Таблица 1 – Тестовые функции и найденные для них оптимумы

Функция	Оптимум	Оптимум, полученный с помощью PSO-метода	Оптимум, полученный с помощью предложенного метода
$f_1 = \sum_{i=1}^{n} \lvert x_i \cdot \sin(x_i) + 0{,}1 \cdot x_i \rvert$, $n = 2$, $-5 \le x_1 \le 5$; $-5 \le x_2 \le 5$.	min: $f_1^*(0; 0) = 0$.	$x_1 = 0{,}004$; $x_2 = 0{,}008$; $f_1^* = 0{,}0013$.	$x_1 = 0{,}0009$; $x_2 = 0{,}005$; $f_1^* = 0{,}00062$.
$f2 = 20 + e - 20\exp\left(-0{,}2\sqrt{\frac{1}{n}\sum_{i=1}^{n} x_i^2}\right) - \exp\left(\frac{1}{n}\sum_{i=1}^{n}\cos(2\pi x_i)\right)$, $n = 2$, $-5 \le x_1 \le 5$; $-5 \le x_2 \le 5$.	min: $f_2^*(0; 0) = 0$.	$x_1 = 0{,}000299$; $x_2 = 0{,}0002$; $f_2^* = 0{,}0010$.	$x_1 = 0{,}00005$; $x_2 = 0{,}00028$; $f_2^* = 0{,}000807$.

Главной особенностью предложенных тестовых функций является их полимодальность, то есть большое количество локальных оптимумов, что позволяет проверить, насколько склонен предложенный метод к зацикливанию в локальных оптимумах.

Графики тестовых функции представлены на рис. 2 и 3.

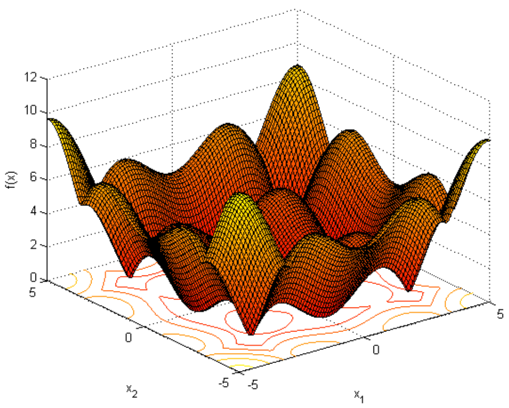


Рисунок 2 – График тестовой функции f_1

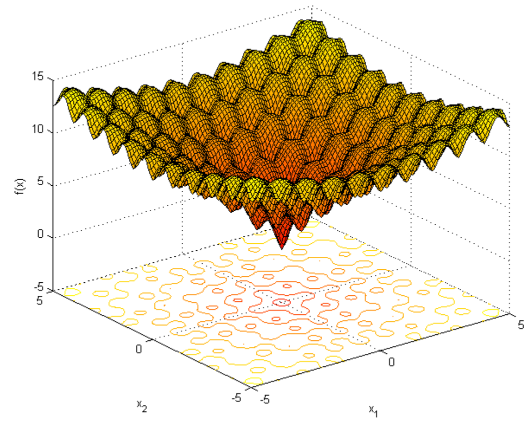


Рисунок 3 – График тестовой функции f_2

Результаты работы разработанного программного обеспечения для соответствующих функций изображены на рис. 4 и 5.

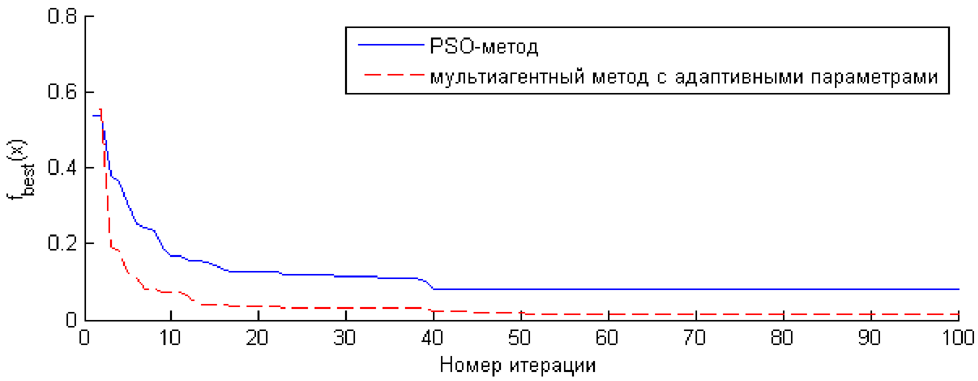


Рисунок 4 – Результаты работы для тестовой функции f_1

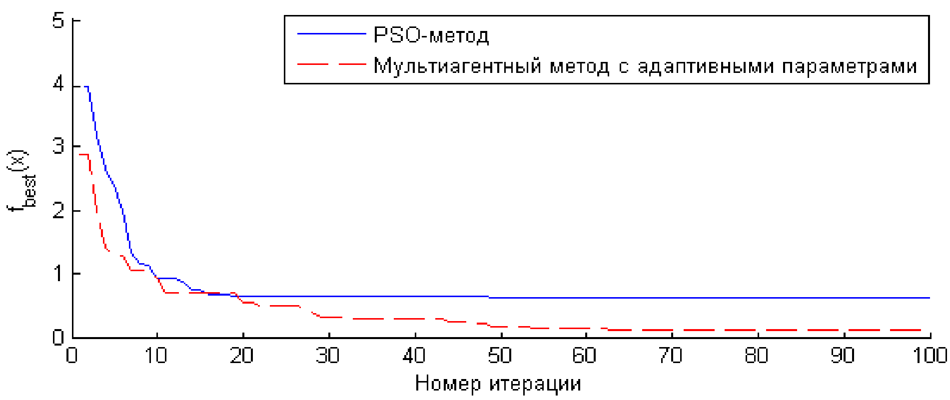


Рисунок 5 – Результаты работы для тестовой функции f_2

Исходя из приведенных результатов можно сделать вывод, что предложенный метод позволяет найти более приемлемые решения по сравнению с известным PSO-методом, основанном на мультиагентном подходе. Кроме того, процесс поиска оптимального значения происходит быстрее по сравнению с базовым методом.

Заключение

В работе решена актуальная задача ускорения работы мультиагентного метода.

Научная новизна работы заключается в том, что предложен мультиагентный метод оптимизации с адаптивными параметрами, который использует процедуры управления изменением скорости перемещения агентов в пространстве поиска, позволяющие исключить нежелательный эффект слишком быстрого возрастания скоростей частиц, что повышает эффективность оптимизационного процесса за счет уменьшения времени поиска оптимального решения.

Практическая ценность результатов работы заключается в том, что разработано программное обеспечение, реализующее предложенный мультиагентный метод оптимизации.

Литература

1. Субботін С.О. Неітеративні, еволюційні та мультиагентні методи синтезу нечіткологічних і нейромережних моделей / Субботін С.О., Олійник А.О., Олійник О.О. ; під заг. ред. С.О. Субботіна. – Запоріжжя : ЗНТУ, 2009. – 375 с.
2. Bonabeau E. Swarm Intelligence: From Natural to Artificial Systems / Bonabeau E., Dorigo M., Theraulaz G. – New York : Oxford University Press, 1999. – 320 p.
3. Dorigo M. The Ant System: Optimization by a Colony of Cooperating Agents / M. Dorigo, V. Maniezzo, A. Colorni // IEEE Transactions on Systems, Man, and Cybernetics. – 1996. – Part B, № 26(1). – P. 29-41.
4. Прогрессивные технологии моделирования, оптимизации и интеллектуальной автоматизации этапов жизненного цикла авиадвигателей : монография / А.В. Богуслаев, Ал.А. Олейник, Ан.А. Олейник и др. ; под ред. Д.В. Павленко, С.А. Субботина. – Запорожье : ОАО «Мотор Сич», 2009. – 468 с.
5. Camazine S. A Model of Collective Nectar Source by Honey Bees: Self-organization Through Simple Rules / S. Camazine, J. Sneyd // Journal of Theoretical Biology. – 1991. – № 149. – P. 547-571.
6. Sumpter D.J. Formalising the Link between Worker and Society in Honey Bee Colonies / D.J. Sumpter, D.S. Broomhead // Lecture Notes In Computer Science : Proceedings of the First International Workshop on Multi-Agent Systems and Agent-Based Simulation (MABS ’98). – Berlin : Springer, 1998. – P. 95-110.
7. Kennedy J. Particle Swarm Optimization / J. Kennedy, R.C. Eberhart // International Conference on Neural Networks : Proceedings of the IEEE. – NJ : IEEE Press, 1995. – P. 1942-1948.
8. De Castro L.N. Artificial Immune Systems. Part I. Basic Theory and Applications / L.N. De Castro, F.J. Von Zuben. – Technical Report No. Rt Dca 01/99. – Brazil : Feec/Unicamp, 1999. – 95 p.
9. Ant System for Job-shop Scheduling / A. Colorni, M. Dorigo, V. Maniezzo et al. // Belgian Journal of Operations Research, Statistics and Computer Science (JORBEL). – 1994. – № 34. – P. 39-53.
10. Субботин С.А. Отбор информативных признаков на основе модифицированного метода муравьиных колоний / С.А. Субботин, А.А. Олейник, В.К. Яценко // Радіоелектроніка та інформатика. – 2006. – № 1. – С. 65-69.
11. Engelbrecht A. Computational Intelligence: an Introduction / Engelbrecht A. – Sidney : John Wiley and Sons Ltd., 2007. – 597p.
12. Abraham A. Swarm Intelligence in Data Mining / A. Abraham, G. Grosan. – Berlin : Springer, 2006. – 267 p.

А.О. Олійник
Мультиагентний метод оптимізації з адаптивними параметрами
Досліджено мультиагентний підхід до оптимізації багатовимірних нелінійних функцій. Розроблено мультиагентний метод оптимізації з адаптивними параметрами. Проведено експерименти по пошуку глобального оптимуму багатовимірної функції на основі запропонованого методу.

A.A. Oliinyk
The Multiagent Optimization Method with Adaptive Parameters
The approach to optimization of multidimensional nonlinear functions is investigated. The multiagent optimization method with adaptive parameters is developed. Experiments on search of global optimum of multidimensional function based on the offered method are made.

Статья поступила в редакцию 28.09.2010.